

This Page Is Inserted by IFW Operations
and is not a part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images may include (but are not limited to):

- BLACK BORDERS
- TEXT CUT OFF AT TOP, BOTTOM OR SIDES
- FADED TEXT
- ILLEGIBLE TEXT
- SKEWED/SLANTED IMAGES
- COLORED PHOTOS
- BLACK OR VERY BLACK AND WHITE DARK PHOTOS
- GRAY SCALE DOCUMENTS

IMAGES ARE BEST AVAILABLE COPY.

As rescanning documents *will not* correct images,
Please do not report the images to the
Image Problem Mailbox.



(19)

(11) Publication number:

09319866 A

Generated Document.

PATENT ABSTRACTS OF JAPAN(21) Application number: **08132222**(51) Intl. Cl.: **G06T 3/40 G06F 15/18**(22) Application date: **27.05.96**

(30) Priority:

(43) Date of application
publication: **12.12.97**(84) Designated contracting
states:(71) Applicant: **SHARP CORP**(72) Inventor: **MATSUOKA TERUHIKO**

(74) Representative:

**(54) IMAGE PROCESSING
METHOD**

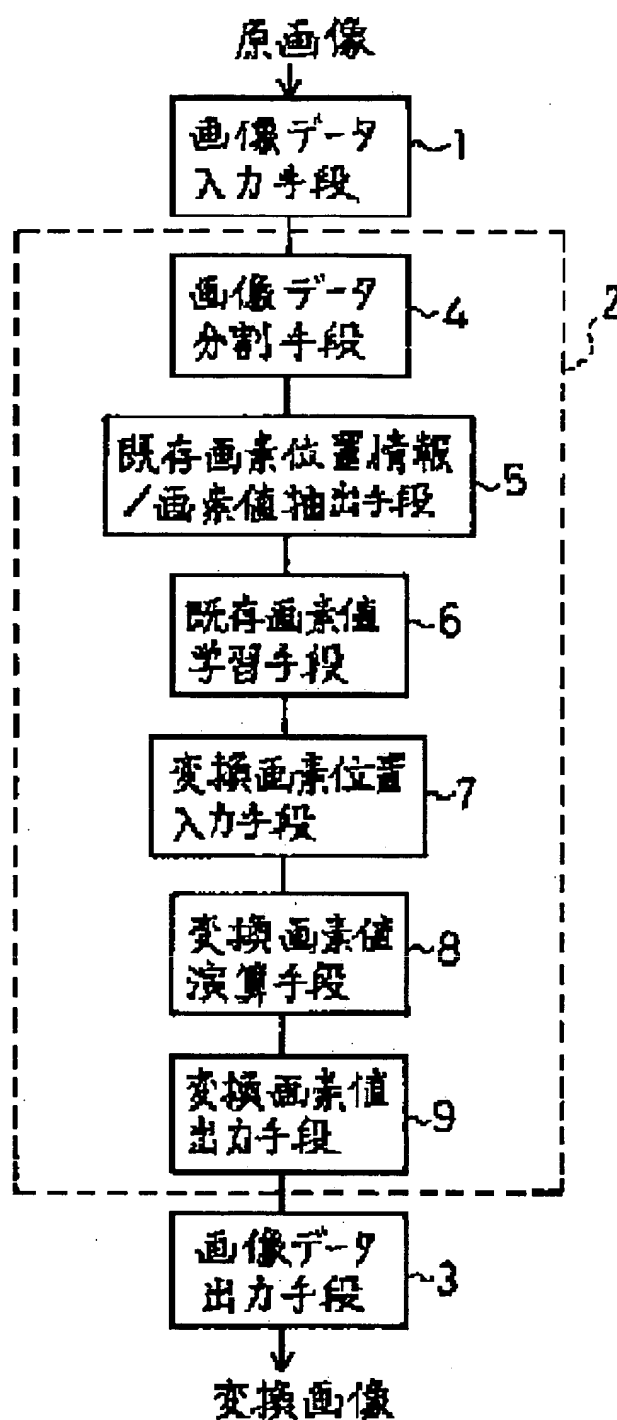
(57) Abstract:

PROBLEM TO BE SOLVED: To provide an processing method which obtains an output image having smooth edge parts and oblique lines for any input image at the time of converting the resolution and magnification of the image.

SOLUTION: A image data input means 1 which inputs an n-gradation ($n > 1$) original image, a image data conversion means 2 which subjects the inputted original image to resolution or magnification conversion processing, a data output means 3 which outputs a converted are provided. The image data conversion means 2 uses a-hierarchical neural network capable of learning for each input image, to perform the conversion processing of each n-gradation input image data divided into plural matrices. Thus, the most suitable conversion processing is always performed, because the

weight of the network can be adjusted for each input image, whatever image is inputted.

COPYRIGHT: (C)1997,JPO



(19) 日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11) 特許出願公開番号

特開平9-319866

(43) 公開日 平成9年(1997)12月12日

(51) Int.Cl. ⁸	識別記号	庁内整理番号	F I	技術表示箇所
G 0 6 T 3/40			G 0 6 F 15/66	3 5 5 C
G 0 6 F 15/18	5 5 0		15/18	5 5 0 G

審査請求 未請求 請求項の数5 OL (全 14 頁)

(21) 出願番号 特願平8-132222

(22) 出願日 平成8年(1996)5月27日

(71) 出願人 000005049

シャープ株式会社

大阪府大阪市阿倍野区長池町22番22号

(72) 発明者 松岡 輝彦

大阪府大阪市阿倍野区長池町22番22号 シ

ャープ株式会社内

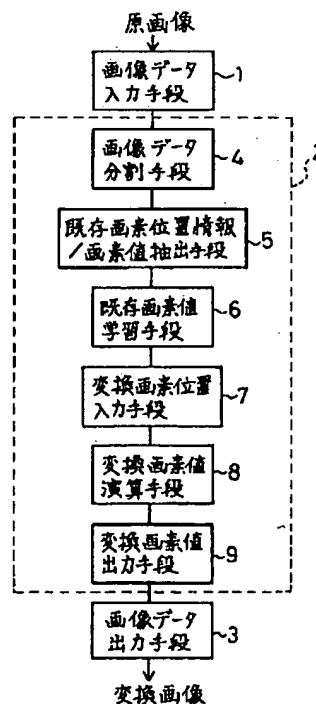
(74) 代理人 弁理士 原 謙三

(54) 【発明の名称】 画像処理方法

(57) 【要約】

【課題】 画像の解像度および倍率を変換したときに、どのような入力画像に対してもエッジ部および斜め線が滑らかな出力画像を得ることのできる画像処理方法を提供する。

【解決手段】 n ($n > 1$) 階調の原画像を入力する画像データ入力手段1と、入力された原画像に対して解像度や倍率の変換処理を行う画像データ変換手段2と、変換画像を出力する画像データ出力手段3とを備える。画像データ変換手段2は、複数のマトリクスに分割した n 階調の入力画像データ毎に、該入力画像毎に学習可能な階層型ニューラルネットワークを用いて上記変換処理を行う。これにより、どのような画像が入力されても、それぞれの入力画像毎にネットワークの重みを調整することができるので、常に最適な変換処理が可能となる。



【特許請求の範囲】

【請求項1】 n ($n > 1$) 階調の入力画像を複数のマトリクスに分割し、これら分割されたマトリクス毎に、入力画像毎に学習可能な階層型ニューラルネットワークを用いて解像度変換処理および変倍処理の少なくとも一方の処理を行い、 n 階調の処理画像を出力画像として得ることを特徴とする画像処理方法。

【請求項2】上記階層型ニューラルネットワークは、入力画像の各画素の位置情報を入力とし、入力された各画素の位置情報における画素値を出力とするように構成されていることを特徴とする請求項1記載の画像処理方法。

【請求項3】上記変換処理を行う際、まず、入力される画像のマトリクス内の既存の画素値を教師データとし、その既存の画素値の位置情報を入力データとして階層型ニューラルネットワークに学習させ、学習終了後、上記変換処理が解像度変換処理であれば、補間画素の位置情報を入力することによって補間画素値を得、また、変倍処理であれば、変倍後の画素の位置情報を入力することによって変倍画素値を得ることを特徴とする請求項1または2記載の画像処理方法。

【請求項4】上記階層型ニューラルネットワークは、2つのノードからなる入力層、少なくとも1つ以上のノードからなる中間層、1つのノードからなる出力層より構成されるバックプロパゲーション型ニューラルネットワークであることを特徴とする請求項2または3記載の画像処理方法。

【請求項5】上記階層型ニューラルネットワークは、2つのノードからなる入力層、big、middle、smallを表現するメンバーシップ関数を構成する2つの層からなるメンバーシップ層、2つの入力に対して全てのメンバーシップ値の組み合わせをとり、ファジィの理論積を得るように構成されるルール層、1つのノードからなる出力層より構成されるファジィ・ニューラルネットワークであることを特徴とする請求項2または3記載の画像処理方法。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】本発明は、 n ($n > 1$) 階調の入力画像に対して変換処理を施して、画像の解像度や倍率を変換して、 n 階調の出力画像を得る画像処理方法に関するものである。

【0002】

【従来の技術】従来より、 n ($n > 1$) 階調の入力画像に対して変換処理を施して、画像の解像度や倍率を変換して、 n 階調の出力画像を得る画像処理方法として種々のものが提案されている。

【0003】画像の解像度を変換する方法として、例えば、図7(a)に示すように、補間前の画素値を補間後の周辺の補間画素値として用いる単純補間法や、図7

(b)に示すように、補間前の画素値の平均値を補間後の画素値として用いる平均法等がある。

【0004】さらに他の画像の解像度を変換する方法として、例えば図7(c)に示すように、補間前の各画素値を直線で結び、この直線上の値を補間値として用いる線形補間法がある。現在、この線形補間法が主流となっている。

【0005】一方、画像の倍率を変換する方法として、例えば図8(a)に示すように、補間前の画素値を補間後の周辺の変倍画素値として用いる単純補間法や、図8(b)に示すように、補間前の画素値の平均値を変倍画素値として用いる平均法等がある。

【0006】さらに他の画像の倍率を変換する方法として、例えば図8(c)に示すように、補間前の各画素値を直線で結び、この直線上の値を補間値として用いる線形補間法がある。現在、この線形補間法が主流となっている。

【0007】ところが、上記の各方法では、解像度変換処理あるいは変倍処理された画像のエッジ部がボケたり、斜め線がギザギザになったりして滑らかさが無くなるという問題が生じる。

【0008】そこで、例えば特開平6-12486号公報には、入力画像に対してニューラルネットワークを用いて非線形な拡大処理を行い、処理後の画像のエッジ部をハッキリとさせ、斜め線のギザギザを目立たなくして滑らかさのある画像を得る『画像補正装置』が開示されている。

【0009】上記画像補正装置では、以下のようにして拡大処理される。まず、2値画像において、注目画素とその右隣、下隣、斜下隣の4画素領域を抽出する。次に、この4画素領域の各画素の値を変更した場合、即ち注目画素を主走査方向にK倍、副走査方向にL倍拡大した場合、この拡大した領域の画素が周囲の画素と滑らかに接続できるような拡大領域の画素を統計的に調べ、その結果を教師信号とし、また、4画素領域の各画素の値を入力信号として予めニューラルネットワークの学習を行う。そして、学習後のニューラルネットワークを用いて、入力された2値画像の拡大処理を行う。

【0010】

【発明が解決しようとする課題】しかしながら、上記公報に開示されている拡大処理では、予め用意された統計的なデータが用いられてニューラルネットワークが学習されているので、学習後のニューラルネットワークの結合の重みは固定される。このため、再学習による重みの微調整ができず、統計的なデータが不十分の場合、入力画像の種類によっては、滑らかな拡大画像を得ることができないという問題が生じる。

【0011】本発明は、上記の問題点を解決するためになされたもので、その目的は、どのような画像が入力されても、画像の解像度および倍率を変換したときに、エ

ッジ部および斜め線が滑らかとなるような出力画像を得ることのできる画像処理方法を提供することにある。

【0012】

【課題を解決するための手段】請求項1の画像処理方法は、上記の課題を解決するために、 n ($n > 1$) 階調の入力画像を複数のマトリクスに分割し、これら分割されたマトリクス毎に、入力画像毎に学習可能な階層型ニューラルネットワークを用いて解像度変換処理および変倍処理の少なくとも一方の処理を行い、 n 階調の処理画像を出力画像として得ることを特徴としている。

【0013】上記の構成によれば、入力画像を、分割したマトリクス毎に、入力画像毎に学習可能な階層型ニューラルネットワークを用いて解像度変換処理や変倍処理を行うようになっているので、出力画像のエッジ部をハッキリさせることができると共に、斜め線をギザギザのない滑らかな線にすることができる。しかも、上記階層型ニューラルネットワークは、入力画像毎に学習可能であるので、随時学習が可能となり、ニューラルネットワークの結合の重み調整を入力画像毎にリアルタイムで行うことができ、入力されるどのような画像に対して入出力関係を最適にすることができる。

【0014】このようなリアルタイムに学習可能な階層型ニューラルネットワークを用いて、分割したマトリクス毎に、解像度変換処理および変倍処理の少なくとも一方の処理が行われると、それぞれの入力画像毎にネットワークの重みを調整することができるので、常に最適な変換処理が可能となる。したがって、どのような入力画像に対しても、変換処理において生じる問題としてのエッジ部分のボケや、斜め線のギザギザを無くすることができるので、変換後の画像に滑らかさが生じ、変換画像の品位を向上させることができる。

【0015】請求項2の画像処理方法に示すように、請求項1の構成に加えて、階層型ニューラルネットワークは、入力画像の各画素の位置情報を入力とし、入力された各画素の位置情報における画素値を出力とするように構成されていることを特徴としている。

【0016】これにより、請求項1の構成による作用に加えて、入力画像に対して解像度変換処理や変倍処理を行うには、階層型ニューラルネットワークは、入力が入力画像の各画素の位置情報だけで十分であり、また、このときの出力が入力画像の各マトリクス内における各位置での画素値であるので、ニューラルネットワークにおける入出力関係が複雑にならずに、規模が小さく、簡単な構造のニューラルネットワークを用いることができる。

【0017】また、請求項3の画像処理方法は、上記の課題を解決するために、請求項1または2の構成に加えて、解像度変換処理や変倍処理を行う際、初めに上記マトリクス内の既存の画素値を教師データとし、その既存の画素値の位置情報を入力データとして階層型ニューラ

ルネットワークに学習させ、学習終了後、解像度変換処理では、補間画素の位置情報を入力することによって補間画素値を得、変倍処理では、変倍後の画素の位置情報を入力することによって変倍画素値を得ることを特徴としている。

【0018】上記の構成によれば、請求項1または2の構成による作用に加えて、解像度変換処理や変倍処理を行う際、階層型ニューラルネットワークの学習方法が、既存画素の位置情報とその既存画素値を用いて行われるので、学習のための計算量が少なく済み、高速に学習を行うことができる。これにより、画像の解像度変換処理や変倍処理の高速化を図ることができる。

【0019】請求項4の画像処理方法は、上記の課題を解決するために、請求項2または3の構成に加えて、階層型ニューラルネットワークは、2つのノードからなる入力層、少なくとも1つ以上のノードからなる中間層、1つのノードからなる出力層より構成されるバックプロパゲーション型ニューラルネットワークであることを特徴としている。

【0020】上記の構成によれば、請求項2または3の構成による作用に加えて、入力画像に対して解像度変換処理や変倍処理を行う場合、階層型ニューラルネットワークとして、2入力1出力のバックプロパゲーション型ニューラルネットワークが用いられているので、入出力関係が簡素であり、簡単なハード構成にて入力画像の変換処理を行うことができる。

【0021】請求項5の画像処理方法は、上記の課題を解決するために、請求項2または3の構成に加えて、階層型ニューラルネットワークは、2つのノードからなる入力層、big、middle、smallを表現するメンバーシップ関数を構成する2つの層からなるメンバーシップ層、2つの入力に対して全てのメンバーシップ値の組み合わせをとり、ファジィの理論積を得るように構成されるルール層、1つのノードからなる出力層より構成されるファジィ・ニューラルネットワークであることを特徴としている。

【0022】上記の構成によれば、請求項1、2または3の構成による作用に加えて、入力画像に対して解像度変換処理や変倍処理を行う場合、階層型ニューラルネットワークとして、2入力1出力のファジィ・ニューラルネットワークが用いられているので、ハード構成上は上記の請求項4記載のバックプロパゲーション型ニューラルネットワークよりも複雑になるものの、より細かい部分画像の階調曲面を表現することが可能となり、請求項4のバックプロパゲーション型ニューラルネットワークより最適な補間画素値あるいは変倍画素値を得ることが可能となる。

【0023】

【発明の実施の形態】本発明の実施の一形態について図1ないし図6に基づいて説明すれば、以下の通りであ

る。

【0024】本実施の形態に係る画像処理方法を適用した画像処理装置は、図1に示すように、画像データ入力手段1と、画像データ変換手段2と、画像データ出力手段3とからなり、 n ($n > 1$) 階調の原画像を入力して、この原画像に対して解像度や倍率の変換処理を施して n 階調の変換画像を出力するようになっている。

【0025】即ち、画像データ入力手段1は、図示しないスキャナ等の画像読取り手段により n 階調の原画像を画像データとして取り込むようになっている。また、画像データ変換手段2は、後述する方法により画像データ入力手段1にて入力された画像データに対して解像度や倍率を変換するようになっている。さらに、画像データ出力手段3は、画像データ変換手段2にて解像度や倍率が変換された画像データをメモリ等の記憶手段に記憶し、その後、この記憶した画像データに対して出力処理を施して、この処理画像を n 階調の変換画像として出力するようになっている。

【0026】上記画像データ変換手段2は、入力された原画像に対して解像度や倍率の変換処理を施すために、画像データ分割手段4、既存画素位置情報／画素値抽出手段5、既存画素値学習手段6、変換画素位置入力手段7、変換画素値演算手段8、変換画素値出力手段9を備えている。

【0027】上記画像データ分割手段4は、画像データ入力手段1により取り込まれた画像データ（以下、入力画像データと称する）を各画素の位置情報に基づいてマトリクス状に分割する手段である。このとき、分割される一つのマトリクスの大きさは、基本的には入力画像データよりも小さければ良く、演算の簡略化、高速化を考慮すれば、マトリクスの縦・横ともに入力画像データの縦・横の画素数の約数となるようにすれば良い。尚、本実施の形態では、入力画像データの大きさを 255×255 画素とし、一つのマトリクスの大きさを 3×3 画素とする。また、入力画像データは、 $n = 256$ 階調、縦・横 $300 \text{ dpi} \times 300 \text{ dpi}$ の解像度とする。

【0028】既存画素位置情報／画素値抽出手段5は、画像データ分割手段4で 3×3 画素の大きさのマトリクスに分割された入力画像データ（以下、部分画像データと称する）に含まれる各画素の位置情報とそれぞれの位置での画素値とを階層型ニューラルネットワークの入力データおよび教師データとして抽出し、これら各データを図示しないメモリに一時的に格納させる手段である。尚、変倍処理を行うとき、既存画素位置情報／画素値抽出手段5にて抽出する各画素の位置情報は、変倍後の位置情報とする。

【0029】上記の画素値とは、画像データの各画素における濃度値や輝度値等の階調を表す値である。また、この画素値から得られる教師データは、階層型ニューラルネットワークがそれぞれの入力値に対して正しい出力

値を出力できるように目標値として与えるデータである。つまり、上記の階層型ニューラルネットワークは、出力値がこの教師データに近づくようにネットワークの結合の重みを変化させていくようになっている。

【0030】既存画素値学習手段6は、既存画素位置情報／画素値抽出手段5でメモリに格納させた画像データの位置情報および上記画像データの各位置での画素値を入力データおよび教師データとして階層型ニューラルネットワークに与えて、該ニューラルネットワークを学習させる。この学習回数は、最高1000回程度とする。しかしながら、学習誤差が5%程度になった場合には、学習回数が1000回に満たなくとも学習を終了する。この学習方法については、後述する。

【0031】本実施の形態では、上記の階層型ニューラルネットワークとして、バックプロパゲーション型ニューラルネットワークとファジィ・ニューラルネットワークとを用いた場合について説明する。尚、各階層型ニューラルネットワークの詳細は、上記学習方法と共に後述する。

【0032】上記既存画素値学習手段6において、階層型ニューラルネットワークの学習が行われると、図2に示すように、既存の画素値を非線形な曲線で結んだときに形成される階調曲面が得られる。図2では、●は既存画素を、○は変換により補間された画素を示し、 x 、 y はそれぞれ入力画素データの x 軸、 y 軸を示し、 z 軸は画素値を示し、入力画像データの x 軸、 y 軸の解像度がそれぞれ2倍となるような解像度変換を行った結果を示している。

【0033】変換画素位置入力手段7は、既存画素値学習手段6で学習された階層型のニューラルネットワークに対して、変換後の各画素の位置情報を入力する手段である。図2における○の x と y の値が、変換後の各画素の位置情報である。

【0034】変換画素値演算手段8は、変換画素位置入力手段7にて位置情報の入力された階層型ニューラルネットワークによりそれぞれの位置での画素値を演算して求める。求めて得られた結果が、図2における○で示された部分であり、それぞれの○の z の値が補間画素値となる。

【0035】変換画素値出力手段9は、変換画素値演算手段8での演算により求められた変換画素値をメモリに記憶させ、その後画像データ出力手段3に変換後の画像データとして出力するようになっている。

【0036】ここで、上記既存画素値学習手段6で使用される2種類の階層型ニューラルネットワークについて、図3ないし図6に基づいて以下に説明する。

【0037】先ず、バックプロパゲーション型ニューラルネットワークについて説明する。本ニューラルネットワークは、図3に示すように、2入力1出力となっており、入力層11、中間層12、出力層13の3層で構成

されている。上記ニューラルネットワークにおいて、2つの入力項目はそれぞれ画素の位置情報であり、1つの出力項目は入力された画素位置における画素値である。

【0038】入力層11は、入力値X1が入力されるノードA1、入力値X2が入力されるノードA2の2つのノードからなる。参照符X1・X2は、画素の位置情報、即ちX1は画素のx軸の位置情報、X2は画素のy軸の位置情報を示す。

【0039】中間層12は、9つのノードD1～D9からなり、これらノードD1～D9は入力層11のノードA1と重みW11～W19で結合されると共に、入力層11のノードA2と重みW21～W29で結合されている。この重みW11～W19、W21～W29は、後述する学習により調整するようになっている。

【0040】尚、中間層12のノード数は、サンプルの画像データを用いて中間層12におけるノード数を1から順に1個ずつ増やして学習させたときに、一番精度良く学習できたときのノード数を用いるようになっている。

$$I_i = x_i \quad [i=1, 2]$$

【0045】ここで、 I_i は入力層11の各ノードからの出力値であり、例えばノードA1からの出力値は I_1 となり、ノードA2からの出力値は I_2 となる。また、 X_i は画素の位置情報を表す入力データを表し、例えばX1は画素のx軸の位置情報、X2は画素のy軸の位置情報を表す入力データを表す。

$$H_j = f(I_i \cdot W_{ij} + \theta 1_j) \quad [j=1, 2, \dots, 9] \quad \dots (2)$$

【0048】ここで、 H_j は中間層12の各ノードからの出力値であり、例えばノードD1からの出力値は H_1 、ノードD2からの出力値は H_2 となる。また、 W_{ij} は入力層11の各ノードと中間層12の各ノードとの結合の度合いを示す重みであり、例えば入力層11のノードA1と中間層12のノードD1との結合の重みは W_{11} である。また、 $\theta 1_j$ は中間層12の各ノードにおけるオフセット値である。

$$f(X) = \frac{1}{1 + e^{-X}}$$

【0051】最後に、出力層13では、中間層12からの出力値に基づいて演算が行われ、ノードE1の出力値が決定される。即ち、中間層12と出力層13との間で

$$O_k = f(H_j \cdot V_{jk} + \theta 2_k)$$

【0053】ここで、 O_k は出力層13のノードE1からの出力値Y1である。また、 V_{jk} は中間層12の各ノードD1～D9と出力層13のノードE1との結合の度合いを示す重みであり、例えば中間層12のノードD1とノードE1との結合の重みは V_{11} である。また、 $\theta 2_k$ は出力層13のノードE1におけるオフセット値である。

【0054】上記の(4)式の($H_j \cdot V_{jk} + \theta 2_k$)を入力値Xとした場合、 $f(X)$ は入力値Xに対して単

調に増加する非線形な単調増加関数であり、例えば図4に示すようなシグモイド関数が適用される。このシグモイド関数は、以下の(3)式で表される。

【0041】出力層13は、1つのノードE1からなり、このノードE1は中間層12のノードD1～D9と重みV11～V91で結合されている。この重みV11～V91は、後述する学習により決定され、出力値Y1として出力されるようになっている。

【0042】上記のように構築されたバックプロパゲーション型のニューラルネットワークの学習方法について以下に説明する。

【0043】まず、入力層11から出力層13までの順方向の演算について説明する。最初に、入力層11では部分画像データの位置情報を入力データ(X1・X2)として入力し、そのまま中間層12に出力する。即ち、以下の(1)式に示すようになる。

【0044】

【数1】

$$\dots \dots (1)$$

【0046】次に、中間層12では、入力層11からの出力値に基づいて演算が行われ、各ノードD1～D9の出力値が決定される。即ち、入力層11と中間層12の間では、以下の(2)式による演算が行われる。

【0047】

【数2】

$$\dots \dots (2)$$

【0049】上記の(2)式の($I_i \cdot W_{ij} + \theta 1_j$)を入力値Xとした場合、 $f(X)$ は入力値Xに対して単調に増加する非線形な単調増加関数であり、例えば図4に示すようなシグモイド関数が適用される。このシグモイド関数は、以下の(3)式で表される。

【0050】

【数3】

$$\dots \dots (3)$$

は、以下の(4)式による演算が行われる。

【0052】

【数4】

$$[k=1] \quad \dots \dots (4)$$

調に増加する非線形な単調増加関数であり、上述した(2)式と同様に、例えば図4に示すようなシグモイド関数が適用される。

【0055】次に、学習のための逆方向の演算について以下に説明する。この学習の目的は、ニューラルネットワークにおける最適な入出力関係を得ることであり、このために、教師データを目標にして、ネットワーク中の結合の重みを微調整するようになっている。以下に、ネットワークの結合の重みの微調整の方法について説明す

る。

【0056】まず、出力層13のノードE1の出力値と教師データとの2乗誤差を、以下の(5)式を用いて計

$$E_k = \frac{(T_k - O_k)^2}{2} \quad \dots\dots (5)$$

【0058】ここで、 E_k は教師データと出力値との2乗誤差であり、 T_k は教師データである。つまり、この学習の目的は、上記 E_k を小さくすることになる。そこで、以下の(6)式を用いて、 E_k を O_k で偏微分する

$$\frac{\partial E_k}{\partial O_k} = -(T_k - O_k) \quad \dots\dots (6)$$

【0060】更に、中間層12と出力層13との間の結合の重み V_{jk} による E_k への影響、および入力層11と中間層12との間の結合の重み W_{ij} による E_k への影響

$$\frac{\partial E_k}{\partial V_{jk}} = -(T_k - O_k) \cdot O_k \cdot (1 - O_k) \quad \dots\dots (7)$$

【0062】

【数8】

$$\frac{\partial E_k}{\partial W_{ij}} = H_j \cdot (1 - H_j) \cdot (-1) \sum_k \left[\frac{\partial E_k}{\partial V_{jk}} \cdot V_{jk} \right] \quad \dots\dots (8)$$

【0063】上記の(7)・(8)式を用いて求めた E_k への影響に基づき、以下の(9)・(10)式を用いて各結合の重みを微調整する。

【0064】

【数9】

$$V_{jk}(t+1) = V_{jk}(t) + \alpha \cdot \frac{\partial E_k}{\partial V_{jk}} \cdot H_j \quad \dots\dots (9)$$

【0065】

【数10】

$$W_{ij}(t+1) = W_{ij}(t) + \alpha \cdot \frac{\partial E_k}{\partial W_{ij}} \cdot I_i \quad \dots\dots (10)$$

【0066】ここで、 α は微調整する度合いを示す値であり、通常0.05~0.25ぐらいの値を用いる。また、 t は学習回数を表している。

【0067】したがって、上記(9)・(10)式では、現在の結合の重み(V_{jk} 、 W_{ij})に微調整する値を加えて、次の演算/学習のときの結合の重みとしている。

【0068】以上のように、上記のアルゴリズムに従って繰り返し学習を行い、結合の重みを修正していくことで、教師データと出力値との2乗誤差をある程度まで小さくできるようになる。そして、予め設定された学習回数、もしくは誤差の値が誤差の許容値以下になった時点で学習を終了する。尚、本実施の形態では、前述した通り規定の学習回数を1000回とし、誤差の許容値は5%とし、学習回数が1000回あるいは誤差が5%以下になった時点で学習を終了するようになっている。

【0069】このように学習されたバックプロパゲシ

算する。

【0057】

【数5】

ことにより、 O_k による E_k への影響を求める。

【0059】

【数6】

を、以下の(7)・(8)式を用いて求める。

【0061】

【数7】

ョン型ニューラルネットワークにより、解像度変換処理や変倍処理を入力された画像の全ての部分画像に対して行うことによって、入力された画像が変換処理され、解像度が変換された画像、もしくは倍率が変換された画像となる。

【0070】次に、ファジィ・ニューラルネットワークについて説明する。本ニューラルネットワークは、図5に示すように、2入力1出力となっており、入力層21、中間層としてのメンバーシップ層前半部22、メンバーシップ層後半部23、ルール層24、および出力層25の5つの層からなり、2層目と3層目を合わせてメンバーシップ層を構築している。上記ファジィ・ニューラルネットワークにおいて、2つの入力項目はそれぞれ画素の位置情報であり、1つの出力項目は入力された画素位置における画素値である。

【0071】上記のファジィ・ニューラルネットワークにおける各層のノードとノードとの間の結合は以下のよ

うにして構成される。

【0072】先ず、入力層21は、入力項目毎に2つのノードA1、A2およびノードA3、A4で構成されており、ノードA2、A4にはそれぞれ定数1が入力され、ノードA1には入力値X1（x軸の位置情報）が入力され、ノードA3には入力値X2（y軸の位置情報）が入力されるようになっている。

【0073】次に、メンバーシップ層では、各入力項目毎に、図6に示すような、big、middle、smallのメンバーシップ関数が構成されている。

【0074】従って、メンバーシップ層前半部22では、ノードB1～B4、ノードB5～B8の各4つのノードを構成し、ノードB1～B4では定数1と入力値X1とを結合させ、ノードB5～B8では定数1と入力値X2とを結合させる一方、メンバーシップ層後半部23では、ノードC1～C3、ノードC4～C5の各3つのノードを構成し、メンバーシップ層前半部22の1つまたは2つのノードを結合させるようになっている。

【0075】即ち、メンバーシップ層前半部22の1つのノードを結合させる部分であるノードC1、C4は、bigのメンバーシップ関数を構成する部分となり、ノードC3、C6は、smallのメンバーシップ関数を構成する部分となる。また、メンバーシップ層前半部22の2つのノードを結合させる部分であるノードC2、C5は、middleを構成する部分となる。

【0076】上記構成のメンバーシップ層の各ノードは、1入力項目毎に必ず構成されるものであり、入力項目毎のノード数は固定である。本実施の形態では、1入力項目に対するメンバーシップ層前半部22のノード数は4、メンバーシップ層後半部23のノード数は3となっている。

【0077】次いで、ルール層24では、メンバーシップ層後半部23の入力値X1に関係するノードC1に対して入力値X2に関係するノードC4～C6のそれぞれと論理積を取るようにノードD1～D3が構成されている。同様にして入力値X1に関係するノードC2に対して入力値X2に関係するノードC4～C6のそれぞれと論理積を取るようにノードD4～D6が構成され、入力値X1に関係するノードC3に対して入力値X2に関係するノードC4～C6のそれぞれと論理積を取るようにノードD7～D9が構成されている。即ち、ルール層24では、2つの入力値X1・X2に対して全てのメンバーシップ値の組み合わせをとり、ファジィの論理積を得るように構成されている。

【0078】最後に、出力層25では、ルール層24からの出力を全て結合し、入力画像の各画素位置での画素値である出力値Y1を出力する1つのノードE1を有している。

【0079】このようにして構成されたファジィ・ニュー

ラルネットワークのノード間の結合部分には、結合毎に全て重みがある。

【0080】従って、入力層21とメンバーシップ層前半部22との結合部分では、メンバーシップ関数のセンター値（メンバーシップ関数の出力値が0.5となる時の入力値）が重み $W_{c11} \sim W_{c14}$ および $W_{c21} \sim W_{c24}$ となっている。

【0081】即ち、メンバーシップ関数は、前述したように3種類あり、それぞれのメンバーシップ関数のセンター値は各重みと一致している。例えば、入力値X1のbigを表すメンバーシップ関数のセンター値の重みは W_{c11} であり、middleを表すメンバーシップ関数のセンター値の重みは W_{c12} と W_{c13} であり、smallを表すメンバーシップ関数のセンター値の重みは W_{c14} である。尚、middleは、2つのメンバーシップ関数の論理積の形となっているので、2つのセンター値を有している。

【0082】次に、メンバーシップ層前半部22とメンバーシップ層後半部23との結合部分では、メンバーシップ関数の傾きが重み $W_{g11} \sim W_{g14}$ および $W_{g21} \sim W_{g24}$ となっている。この場合、メンバーシップ関数の傾きが各重みと一致している。例えば、入力値X1のbigを表すメンバーシップ関数の傾きの重みは W_{g11} であり、middleを表すメンバーシップ関数の傾きの重みは W_{g12} と W_{g13} であり、smallを表すメンバーシップ関数の傾きの重みは W_{g14} である。尚、middleは、2つのメンバーシップ関数の論理積の形となっているので、2つの傾きを有している。

【0083】最後に、ルール層24と出力層25との結合部分では、エキスパートから得た知識が重み $W_{f1} \sim W_{f9}$ となっている。このエキスパートから得た知識では、出力値が大きくなるような入力値の組み合わせのルールの重みは1に近い値とし、出力値が小さくなるような入力値の組み合わせのルールの重みは0に近い値とする。それ以外のルールの重みは0.5に初期設定しておく。

【0084】また、上述した結合部分以外の結合部分の重み、例えばメンバーシップ層後半部23とルール層24との結合部分の重みは、1で固定されている。

【0085】上記構成のファジィ・ニューラルネットワークにおいて、各層の出力値を求める方法について以下に説明する。尚、入力層21の出力値は、入力値と同じであるので説明は省略する。

【0086】メンバーシップ層は、以下の(11)式に示すように、2層目でメンバーシップ関数のセンター値 $W_{c11} \sim W_{c14}$ および $W_{c21} \sim W_{c24}$ を加える。

【0087】

【数11】

$$H_{i+j} = x_j + w_{cij} \\ (w_{cij} < 0; i=1, 2; j=1, 2, 3, 4) \dots (11)$$

【0088】ここで、 x は入力層21の出力値、 W_c はメンバーシップ関数のセンター値、 H は2層目の出力である。また、 i は各入力項目の数であり、 j はbigのとき1、middleのとき2または3、smallのとき4となっている。

【0089】上記(11)式は、後に代入する以下の(12)式に示すようなシグモイド関数の原点の位置をメンバーシップ関数のセンター値の位置に合わせることを示している。

$$f(X) = \frac{1}{1+e^{-X}} \dots (12)$$

【0092】

$$M_{ik} = f(H_{ij} \cdot w_{gij}) \quad (k=1, 2, 3) \dots (13)$$

【0093】

$$M_{ik} = \min \{ f(H_{ij} \cdot w_{gij}), f(H_{i(j+1)} \cdot w_{gi(j+1)}) \} \dots (14)$$

【0094】ここで、 W_g はメンバーシップ関数の傾きの値、 $f(X)$ はシグモイド関数、 M はメンバーシップ関数の出力値、 $\min \{ f(X1), f(X2) \}$ は $f(X1)$ と $f(X2)$ との論理積を示す。また、 k はメンバーシップ層後半部23のノードの番号であり、 θ はbigのとき1、middleのとき2、smallのとき3となっている。また、上記(14)式では、論理積を計算することにより、 \min のカッコの中の2つの

$$R_n = \min \{ M_{i1k1} \cdot M_{i2k2} \} \\ (i_1 < i_2; i_1=1, i_2=2; k_1, k_2=1, 2, 3) \dots (15)$$

【0097】ここで、 R はAND規則の出力値であり、 $k1$ と $k2$ はメンバーシップ層後半部23のノード番号である。また、ここでも論理積の計算により、 \min のカッコの中の2つの関数のうち、小さい方の値を選択することになる。

【0098】最後に、出力層25では、以下の(16)式を用いて出力値の計算が行われる。即ち、ファジィル

$$y = \frac{\sum_{n=1}^9 (R_n \cdot w_{fn})}{\sum_{n=1}^9 R_n} \dots (16)$$

【0100】ここで、 n はルール層24のノード番号である。

【0101】以上が、上記のファジィ・ニューラルネットワークに入力値を代入してから出力値を得るまでの計算の過程を示す。尚、上記構成のファジィ・ニューラルネットワークを初めに構築した状態では、各層のノード間の結合の重みの値は各層毎に決まった値を有してお

【0090】次に、以下の(13)式に示すように、3層目でメンバーシップ関数の傾きを掛けてシグモイド関数に代入することにより、その入力値の各領域でのメンバーシップ関数の出力値を得るようになっている。尚、middleの場合は(13)式の代わりに以下の(14)式を用いる。

【0091】

【数12】

【数13】

【数14】

関数のうち、小さい方の値を選択することになる。

【0095】次いで、ルール層24では、以下の(15)式を用いてAND規則の計算が行われる。即ち、2つの入力項目の中で、それぞれ3つの領域(big、middle、small)から1つずつ選び、その2つのメンバーシップ出力値の論理積の計算が行われる。

【0096】

【数15】

ールの前件部命題(例：X1がbigである)によって得られた各AND規則の出力値とそのルールからの結合の重みの値 W_f を掛け合わせて、それをAND規則の出力全体の合計値で割ったものの総和を取ることによって計算が行われる。

【0099】

【数16】

り、入力値を代入しても、出力値はでたためな値であり、対象物の入出力関係を正しくシミュレートできない。そこで、正しくシミュレートするために、結合の重みの調整を行う必要がある。これがファジィ・ニューラルネットワークにおける学習である。

【0102】上記ファジィ・ニューラルネットワークにおける学習について以下に説明する。

【0103】対象物の入出力関係を表したサンプルデータの出力値を教師データTとし、以下の(17)式を用いて、この教師データTと、サンプルデータの入力値(X1、X2、…、Xn)から上記の(11)～(1

$$E = \frac{1}{2} (T-y)^2$$

【0105】ここで、Eは教師データTと出力値yとの2乗誤差を表す。この誤差を少なくすることによって対象物の入出力関係が正しくシミュレートできているものと判断する。

【0106】この誤差を減らす方法として、バックプロパゲーション法に基づいて学習アルゴリズムを用いる。

$$\frac{\partial E}{\partial y} = -(T-y)$$

【0109】次いで、上記(17)式をWfにおいて偏微分すると、以下の(19)式に示すようになる。このとき、上記(17)式のyに上記(16)式を代入す

$$\frac{\partial E}{\partial w_{fp}} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial w_{fp}} = -(T-y) \frac{R_p}{\sum_{n=1}^p R_n} \quad \dots\dots\dots (19)$$

【0111】次に、上記(17)式をWg、Wcにおいてそれぞれ偏微分すると、以下の(20)(21)式に示すようになる。このとき、上記(17)式に、上記(16)式、(15)式および(14)式、または(1

$$\begin{aligned} \frac{\partial E}{\partial w_{gij}} &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial R_p} \frac{\partial R_p}{\partial M_{ik}} \frac{\partial M_{ik}}{\partial w_{gij}} \\ &= -(T-y) \cdot \sum_r \left[\frac{w_{fp} \sum_{n=1}^p R_n - \sum_{n=1}^p (R_n \cdot w_{fn})}{\left(\sum_{n=1}^p R_n \right)^2} \right] \cdot M_{ik} \cdot (1-M_{ik}) \cdot H_{ij} \end{aligned} \quad \dots\dots\dots (20)$$

【0113】

【数21】

$$\begin{aligned} \frac{\partial E}{\partial w_{cij}} &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial R_p} \frac{\partial R_p}{\partial M_{ik}} \frac{\partial M_{ik}}{\partial H_{ij}} \frac{\partial H_{ij}}{\partial w_{cij}} \\ &= -(T-y) \cdot \sum_r \left[\frac{w_{fp} \sum_{n=1}^p R_n - \sum_{n=1}^p (R_n \cdot w_{fn})}{\left(\sum_{n=1}^p R_n \right)^2} \right] \cdot M_{ik} \cdot (1-M_{ik}) \cdot H_{gij} \end{aligned} \quad \dots\dots\dots (21)$$

【0114】上記(19)～(21)式までが誤差に対するそれぞれの結合の重みの影響を示す。ここで、上記(20)式および(21)式におけるrは修正すべきメンバーシップ関数を実現している重みからANDルールの出力として選択された数だけ、ルール層24のノードからの誤差の総和を取っている。

$$\Delta w_{fp} = -\alpha \frac{\partial E}{\partial w_{fp}}$$

6)式によって得られた出力値yとの2乗誤差を用いる。

【0104】

【数17】

..... (17)

以下、この学習アルゴリズムについて説明する。

【0107】上記(17)式をyにおいて偏微分すると、以下の(18)式に示すようになる。これが、誤差に対する出力値yの影響を示す。

【0108】

【数18】

..... (18)

る。

【0110】

【数19】

3)式、(11)式を代入する。

【0112】

【数20】

【0115】これらの影響が少なくなる方向に重みを修正することによって、全体的に誤差を減らすように示すようになる。

【0116】

【数22】

..... (22)

【0117】

$$\Delta w_{gij} = -\beta \frac{\partial E}{\partial w_{gij}}$$

【0118】

$$\Delta w_{cij} = -\gamma \frac{\partial E}{\partial w_{cij}}$$

【0119】ここで、 α 、 β 、 γ は学習パラメータであり、影響を小さくする重みの修正量を決定するためのパラメータである。このパラメータを用いて、以下の(2

$$w_{fp} = w_{fp} + \Delta w_{fp}$$

【0121】

$$w_{gij} = w_{gij} + \Delta w_{gij}$$

【0122】

$$w_{cij} = w_{cij} + \Delta w_{cij}$$

【0123】以上のような学習アルゴリズムに従って繰り返し学習を行い、重みを修正することで誤差を小さくしている。そして、誤差の値が予め設定した誤差の許容値以下になった時点で学習を終了とする。この誤差の許容値は予め設定されるものであり、本実施の形態では5%以下になった時点で学習を終了するものとする。

【0124】このように学習されたファジィ・ニューラルネットワークにより、解像度変換処理や変倍処理を、入力された画像の全ての部分画像に対して行うことによって、上述したバックプロパゲーション型ニューラルネットワークよりも適切に入力された画像が変換処理され、解像度が変換された画像、もしくは倍率が変換された画像を得ることができる。

【0125】本実施の形態における画像処理方法では、解像度変換処理や変倍処理を行う際、先ず、上記画像データ分割手段4にて分割されたマトリクス内の既存の画素の画素値を教師データとし、その既存の画素の画素値に対応する位置情報を入力データとして既存画素値学習手段6にて階層型ニューラルネットワークに学習させ、学習終了後、解像度変換処理であれば、補間画素の位置情報を入力することによって補間画素値を得、変倍処理であれば、変倍後の画素の位置情報を入力することによって変倍画素値を得るようになっている。

【0126】このように、入力画像を、分割したマトリクス毎に、入力画像毎に学習可能な階層型ニューラルネットワークであるバックプロパゲーション型ニューラルネットワークやファジィ・ニューラルネットワークを用いて解像度変換処理や変倍処理が行われるので、出力画像のエッジ部をハッキリさせることができると共に、斜め線をギザギザのない滑らかな線にすることができる。

【0127】しかも、上記階層型ニューラルネットワー

【数23】

..... (23)

【数24】

..... (24)

5)～(27)式に示すような修正が行われる。

【0120】

【数25】

..... (25)

【数26】

..... (26)

【数27】

..... (27)

クは、入力画像毎に学習可能であるので、入力されるどのような画像に対して入出力関係を最適にすることができる。このようなリアルタイムに学習可能な階層型ニューラルネットワークを用いて、分割したマトリクス毎に、解像度変換処理および変倍処理の少なくとも一方の処理が行われると、それぞれの入力画像毎にネットワークの重みを調整することができるので、常に最適な変換処理が可能となる。

【0128】したがって、どのような入力画像に対しても、変換処理において生じる問題としてのエッジ部分のボケや、斜め線のギザギザを無くすることができるので、変換後の画像に滑らかさが生じ、変換画像の品位を向上させることができる。

【0129】また、上記画像処理方法における階層型ニューラルネットワークは、入力画像の各画素の位置情報を入力とし、入力された各画素の位置情報における画素値を出力するように構成されている。

【0130】このように、入力画像に対して解像度変換処理や変倍処理を行うには、階層型ニューラルネットワークは、入力が入力画像の各画素の位置情報だけで十分であり、また、このときの出力が入力画像の各マトリクス内における各位置での画素値であるので、ニューラルネットワークにおける入出力関係が複雑にならずに、規模が小さく、簡単な構造のニューラルネットワークを用いることができる。

【0131】さらに、本画像処理方法では、解像度変換処理や変倍処理を行う際、階層型ニューラルネットワークの学習方法が、既存画素の位置情報とその既存画素値を用いて行われるので、学習のための計算量が少なく済み、高速に学習を行うことができる。これにより、画像の解像度変換処理や変倍処理の高速化を図ることがで

きる。

【0132】そして、入力画像に対して解像度変換処理や変倍処理を行う場合、画像処理方法に適用される階層型ニューラルネットワークとしてバックプロパゲーション型ニューラルネットワークが用いられているので、入力画像に対して解像度変換処理や変倍処理を行う場合、簡素なハード構成にて入力画像の変換処理を行うことができる。

【0133】さらに、入力画像に対して解像度変換処理や変倍処理を行う場合、階層型ニューラルネットワークとして、2入力1出力のファジィ・ニューラルネットワークが用いられているので、ハード構成上は上記のバックプロパゲーション型ニューラルネットワークよりも複雑になるものの、より細かい部分画像の階調曲面を表現することが可能となり、バックプロパゲーション型ニューラルネットワークより最適な補間画素値あるいは変倍画素値を得ることが可能となる。

【0134】尚、本実施の形態では、階層型ニューラルネットワークとして、図3に示すバックプロパゲーション型ニューラルネットワークや、図5に示すファジィ・ニューラルネットワークを用いたが、これらに限定するものではなく、入力層から出力層へ向かう結合のみがある他の階層型ニューラルネットワークを用いても同様の効果を奏する。

【0135】

【発明の効果】請求項1の発明の画像処理方法は、以上のように、 n ($n > 1$) 階調の入力画像を複数のマトリクスに分割し、これら分割されたマトリクス毎に、入力画像毎に学習可能な階層型ニューラルネットワークを用いて解像度変換処理および変倍処理の少なくとも一方の処理を行い、 n 階調の処理画像を出力画像として得る構成である。

【0136】それゆえ、どのような画像が入力されても、それぞれの入力画像毎にネットワークの重みを調整することができるので、常に最適な変換処理が可能となる。これにより、各変換処理において生じる問題としてのエッジ部分のボケや、斜め線のギザギザを無くすることができるので、変換後の画像に滑らかさが生じ、変換画像の品位を向上させることができるという効果を奏する。

【0137】請求項2の発明の画像処理方法は、以上のように、請求項1の構成に加えて、階層型ニューラルネットワークは、入力画像の各画素の位置情報を入力とし、入力された各画素の位置情報における画素値を出力とするように構成されている。

【0138】それゆえ、請求項1の構成による効果に加えて、階層型ニューラルネットワークとして、規模が小さく、簡単な構造のニューラルネットワークを用いることができるという効果を奏する。

【0139】請求項3の発明の画像処理方法は、以上の

ように、請求項1または2の構成に加えて、解像度変換処理や変倍処理を行う際、初めに上記マトリクス内の既存の画素値を教師データとし、その既存の画素値の位置情報を入力データとして階層型ニューラルネットワークに学習させ、学習終了後、解像度変換処理では、補間画素の位置情報を入力することによって補間画素値を得、変倍処理では、変倍後の画素の位置情報を入力することによって変倍画素値を得る構成である。

【0140】それゆえ、請求項1または2の構成による効果に加えて、解像度変換処理や変倍処理を行う際、階層型ニューラルネットワークの学習方法が、既存画素の位置情報とその既存画素値を用いて行われるので、学習のための計算量が少なく済み、高速に学習を行うことができる。これにより、画像の解像度変換処理や変倍処理の高速化を図ることができるという効果を奏する。

【0141】請求項4の発明の画像処理方法は、以上のように、請求項2または3の構成に加えて、階層型ニューラルネットワークは、2つのノードからなる入力層、少なくとも1つ以上のノードからなる中間層、1つのノードからなる出力層より構成されるバックプロパゲーション型ニューラルネットワークである。

【0142】それゆえ、請求項2または3の構成による効果に加えて、入力画像に対して解像度変換処理や変倍処理を行う場合、階層型ニューラルネットワークとして、2入力1出力のバックプロパゲーション型ニューラルネットワークが用いられているので、簡素なハード構成にて入力画像の変換処理を行うことができるという効果を奏する。

【0143】請求項5の発明の画像処理方法は、以上のように、請求項2または3の構成に加えて、階層型ニューラルネットワークは、2つのノードからなる入力層、big、middle、smallを表現するメンバーシップ関数を構成する2つの層からなるメンバーシップ層、2つの入力に対して全てのメンバーシップ値の組み合わせをとり、ファジィの理論積を得るように構成されるルール層、1つのノードからなる出力層より構成されるファジィ・ニューラルネットワークである。

【0144】それゆえ、請求項2または3の構成による効果に加えて、入力画像に対して解像度変換処理や変倍処理を行う場合、階層型ニューラルネットワークとして、2入力1出力のファジィ・ニューラルネットワークが用いられているので、ハード構成上は上記の請求項4記載のバックプロパゲーション型ニューラルネットワークよりも複雑になるものの、より細かい部分画像の階調曲面を表現することが可能となり、請求項4のバックプロパゲーション型ニューラルネットワークより最適な補間画素値あるいは変倍画素値を得ることができるという効果を奏する。

【図面の簡単な説明】

【図1】本発明の画像処理方法を適用した画像処理装置

の概略ブロック図である。

【図2】階調曲面を示す説明図である。

【図3】図1に示す画像処理装置に適用される階層型ニューラルネットワークとしてのバックプロパゲーション型のニューラルネットワークを示す模式図である。

【図4】シグモイド関数を示すグラフである。

【図5】図1に示す画像処理装置に適用される階層型ニューラルネットワークとしてのファジィ・ニューラルネットワークを示す模式図である。

【図6】メンバーシップ関数を示すグラフである。

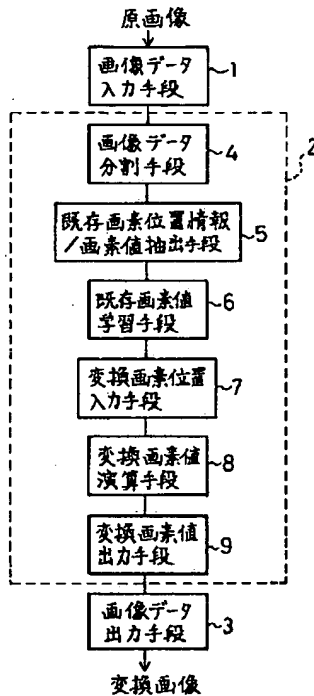
【図7】従来の画像処理方法における解像度変換方法を示す説明図である。

【図8】従来の画像処理方法における変倍処理方法を示す説明図である。


【符号の説明】

- 1 画像データ入力手段
- 2 画像データ変換手段
- 3 画像データ出力手段
- 4 画像データ分割手段
- 5 既存画素位置情報／画素値抽出手段
- 6 既存画素値学習手段
- 7 変換画素位置入力手段
- 8 変換画素値演算手段
- 9 変換画素値出力手段


【図1】




【図2】




【図3】




【図4】








【図5】



【図6】



【図7】



【図8】

